

# 机器学习：解方程(Equation Solving)

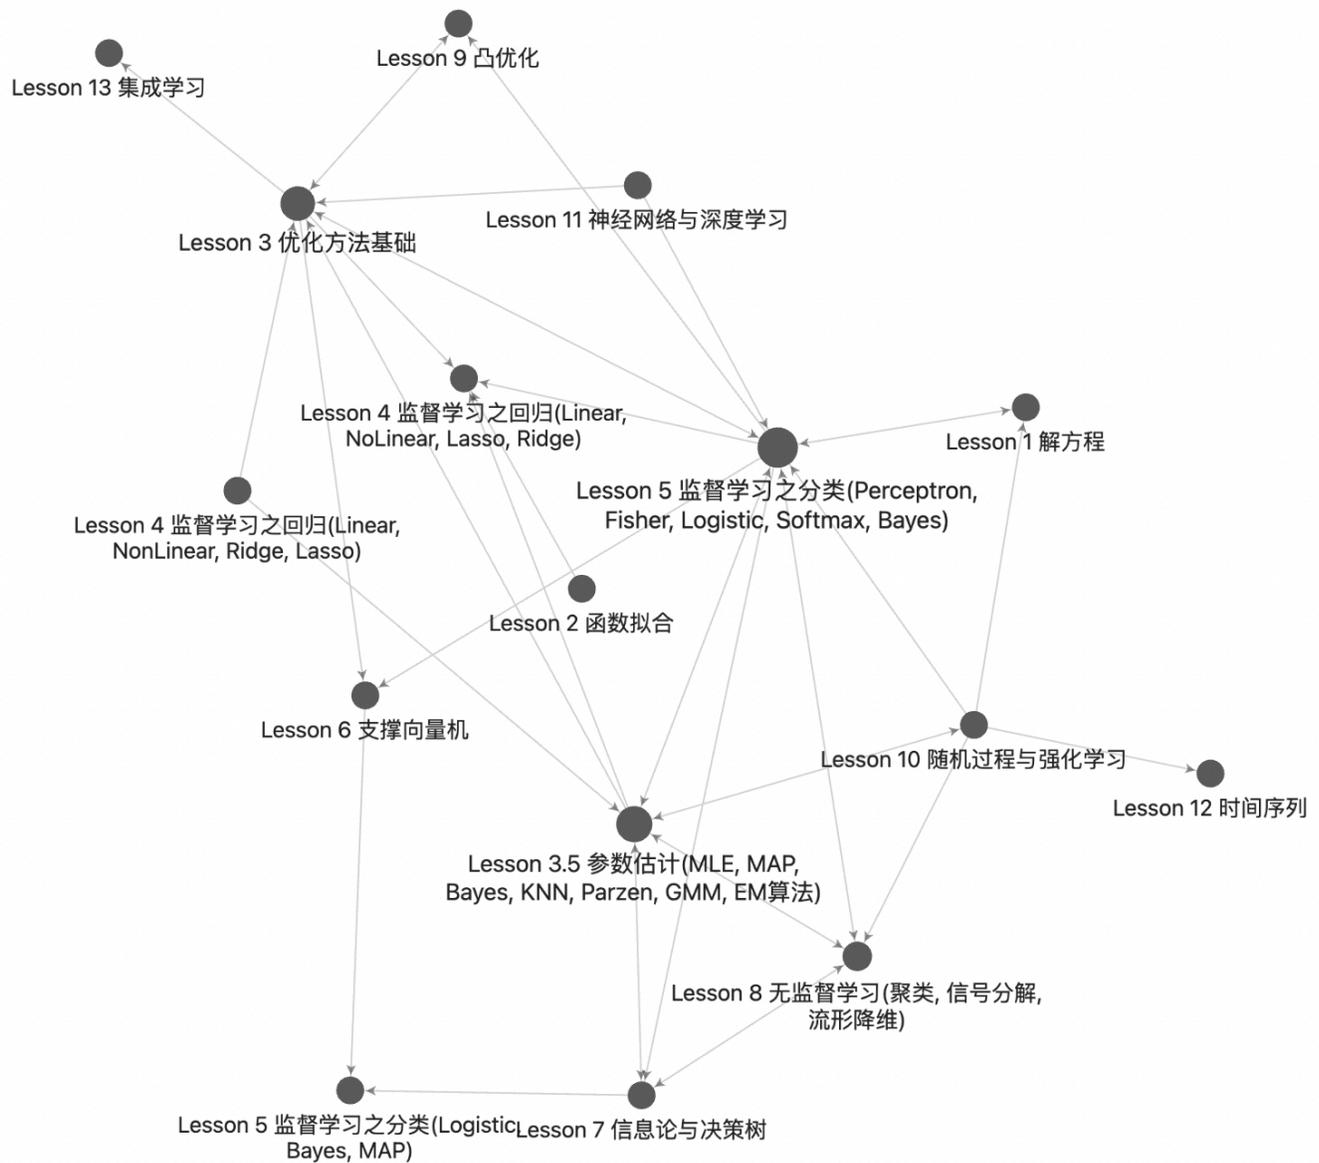
Copyright: Jingmin Wei, Automation - Pattern Recognition and Intelligent System, School of Artificial Intelligence and Automation, Huazhong University of Science and Technology

Copyright: Jingmin Wei, Computer Science - Artificial Intelligence, Department of Computer Science, Viterbi School of Engineering, University of Southern California

---

机器学习：解方程(Equation Solving)

1. 数据科学基础课堂&课后笔记的最佳食用方法
  2. 解方程
  3. 高斯消元法
  4.  $LU$  分解法
  5. 迭代法(高斯消元)
  6. 高斯 - *Sedel* 法
  7. 优化法
  8. 特征值法
-



在华科 A 院学习机器学习两年多，却被在 USC 的机器学习课彻底打败，本科课堂也唯有曹老板的模式识别前短短四周能与之抗衡，除了感慨教育质量之差距，也感慨 ML 理论世界之魅力。Vatsal 教授上课徒手推公式，生动形象阐述每一个算法，理论完整，逻辑清晰(不愧是斯坦福博士 MIT 博后，膜)，让自己感觉好像还是个刚入门的萌新。个人以为，ML 理论真的很重要。大家都说深度学习入门简单，看个代码调个参，调个包，不断做消融实验就能出结果，可是当真正涉及模型改进的时候，这些基础理论以及优化算法，才是能帮助到你的知识。

## 1. 数据科学基础课堂&课后笔记的最佳食用方法

该笔记的主体是 AIA 数据科学基础的课堂笔记，完全是个人下课后手打的，一开始只是想完成这门课的大作业，也就是每个人都要抄老师规定部分的课堂笔记。后来觉得袁老师讲得太好了，所以每堂课就全部记下来了。之后刷完了一本 400 多页的数学书，闲着无聊把西瓜书挑着看了一遍，然后又在 USC 上了老师的机器学习课，索性把笔记从头到尾优化了一遍。之后我会把这部分笔记和 USC 上机器学习课记的英文笔记一并上传 github。

主要参考资料有：数据科学基础课堂和课后笔记(主体)，西瓜书，《机器学习中的数学》，模式识别部分课件，一些经典的论文，*csdn*上的一些大佬的文章。

尤其要感谢一下花姐当时每天上课帮我扫描 *pdf*。因为老师不准外传笔记的原因，所以笔记和板书我都是上课的时候拍下来或者拜托花姐帮我拍，回头每天上课花 3 小时左右全部补上。袁焯老师的板书写得非常好，所以他的所有内容我都抄下来了。有时候其他的老师会用课件讲课，课后我也把每页课件都补上了。

首先简单说下数据科学的定义。*Data Science* 在国外，尤其是在美国，是需要和具体内容和知识领域结合的，比如说 *DS in health, DS in Environment Engineering, DS and Analytics*，可见数据科学是一个广义上的概念，也有专门数据科学的硕士学位。而这门课的内容，更准确来说，是在讲机器学习，或者说是机器学习中的数学推导。其实如果大家的 *Prerequisite* 有模式识别或者机器学习，上这门课会更好理解。但是考虑到大家没上模式识别，所以我从开学开始一直在完善笔记的内容，争取让很多算法的入门门槛变得更低。

*ML From Probability Perspective*，也就是从概率论角度理解机器学习，其实是最合适的。但是本科的模式识别这门课，其实更多是从梯度下降的优化算法讲起，重点是带大家理解"学习"。而数据科学基础这门课，又是从一些基本的计算方法开始讲起的，并没有详细讲梯度下降，而是着重于不同的优化方法，也掺杂了一元多元微积分，矩阵，概率论的一些知识，重点是带大家理解"优化"。所以为了方便大家理解一些重要算法，我加了第 3.5 章：概率密度函数的估计，概率论中的最大似然，最大后验，贝叶斯这三个思路非常重要，也能帮大家更好的理解之后的线性回归，正则化，逻辑回归等一些经典算法的原理，同时也帮大家理解机器学习从概率角度出发，到底需要完成一个怎样的任务。

最后列一下每章的概要和重点。有些是老师上课没讲的，完全是我课后补充的内容，我也列出来了，大家这部分的算法可以根据需求自己选看。

第 1,2 章是一些基础的解方程和函数拟合问题，这里我没有额外补充，这两个部分也是我被袁焯老师圈粉的部分，讲得深入浅出，后面就开始蒙了。

第 3 章是袁老师教的，讲一些基本的优化方法。其中黑塞矩阵，极值判别法则等等数学部分都很重要。在一阶优化算法的部分，除了梯度下降算法，其他算法都是我自己后面加上去的，其中一阶牛顿法我主要是参考的计算方法的课件，老师上课并没有讲随机梯度下降，这一部分的概念很重要且非常容易混淆，且是后面多个算法优化的重要内容，推荐大家认真看下 *SGD* 及其变种，当时我刚好在写 *PyTorch* 优化器的源码分析，顺便就把多个不同的优化算法的内容写上去了。后面的二阶优化方法和分治法，也都是我之后补充上去的。

第 3.5 章参数估计，全部内容都是我之后加的，是我觉得很重要的知识点，不夸张的说，最大似然估计几乎贯穿了整个机器学习的理论推导。数据科学的课堂上并没有这部分内容，而是把这部分穿插在了 4,5 两章来讲解，但是模式识别的老师讲了(虽然讲的顺序我也觉得有问题)。原则上是选看，但是我觉得不看 3.5 章理解 4,5 两章可能会存在一定困难，尤其是经典的抛硬币问题，非常推荐大家在老师讲基本的回归分类算法前看一下。变分推断会比较难，看不懂没关系，因为我也不太懂... *GMM, EM* 也是非常经典的参数估计方法，值得一看。

第 4 章是袁老师教的，讲基本的回归算法。\*\*其中，线性回归的梯度下降优化方法是我加上去的，这一部分很重要，之后的所有随机梯度下降的算法阐述将沿用这一框架。因为老师当时重点是从最大似然和最大后验角度出发讲优化算法，随机梯度下降是我之后补上去的。

第 5 章讲基本的分类算法，袁老师上课讲了 *Logistic, Bayes* 是程骋老师教的，但是这两个部分也有很多没讲清楚。这一章其中的大部分都是我后期加上去的：感知机，线性判别分析，以及 *Softmax* 回归，这些是我认为比较基础但是也很重要的分类算法。逻辑回归部分，我补充了 *Sigmoid* 函数的推导，损失函数的梯度计算，分治法的优化；*Bayes* 我补充了高斯贝叶斯模型部分。

第 6 章是袁老师教的，支撑向量机也是我觉得最难的一章之一，我也补充了非常多的内容。添加了二次规划求解，软间隔问题，分治法，支撑向量的判断等，同时补充了核方法的部分。这里是我当时完全听不懂的一章，我本来以为模式识别我学的很明白了，上了数据科学才发现自己只看懂了合页损失和  $KKT$  条件。这一章的拉格朗日对偶方法是一个非常重要的优化算法，大家可以多看看。

第 7 章是程老师教的，主要是讲信息论和决策树。这里我把信息论部分的数学公式和一些熵的性质都补充完整了，并添加了  $KL, JS$  散度部分。这里程老师上课的顺序有点问题，是先讲的决策树然后再讲的信息论，其实先学懂信息论基础再看决策树会简单很多，所以我调整了一下顺序，同时我也把第 7,8 章的上课顺序调换了一下。

第 8 章主要讲无监督学习中的几个常用算法，袁老师教的局部线性嵌入  $LLE$  和  $K - Means$ ，程老师教的  $PCA$ 。袁老师的板书写得很好，但是局部线性嵌入的一堆公式根本听不懂。我补充了  $Mean - Shift$  聚类算法，基于  $PCA$  的优化目标，补充了矩阵的特征值和奇异值分解计算。流形学习部分，除了局部线性嵌入  $LLE$ ，我补充了随机近邻嵌入  $SNE$  和谱嵌入  $LE$  算法。无监督学习很重要，但是算法的数学推导其实挺难的，实在看不懂不用勉强。

第 9 章是袁老师当时请了东北大学一个控制系的老师来教的。说是 90 分钟讲清楚凸优化，讲到后面我除了凸集之外啥都没听懂，后面还搁那介绍自己实验室。所以这里我只补充了一些凸优化问题的基本概念，相关知识的深入大家可以自行查阅凸优化的资料。

第 10 章是袁老师教的，主要是讲强化学习。当时上课的时候也是不知所云，袁老师上课的板书还是很好看的，缺点就是我啥也听不懂。所以为了方便大家理解，这章我补充了一些随机过程里的东西，包括马尔科夫过程，隐马尔科夫模型等等，然后把强化学习的笔记部分补充了一下。

第 11 章就不多说了，程老师教的，介绍了一些神经网络的基本概念。详细的可以看[我的专栏](#)。其中，老师上课没讲过的半监督学习算法在专栏里的图卷积网络部分，有兴趣可以了解一下。

第 12 章没有额外补充，当时是岳作功老师教的，讲得还是很清晰的。

第 13 章也是岳老师教的，讲得也挺好的。我只补充了基于分治法的  $AdaBoost$  优化算法推导和  $Stacking$  算法。岳老师上课没讲  $Stacking$ ，我觉得这个理解很简单，就是拿第一级强分类器的概率图输出作为第二级弱分类器的输入，缓解过拟合，所以我也没过多补充。

说一下我认为的重点章节：**3, 3.5, 4, 5, 6, 8**，这些之后模式识别还会再讲一遍。当然，第 11 章也重要但是这部分当时是程老师念的  $Slide$ ，神经网络的理论和最佳实践更看大家自己去学习和总结。

笔记的最佳食用方式已经留给大家了，充分使用看个人。

## 2. 解方程

从解方程开始： $Ax = b$

$$\begin{cases} x_1 + x_2 + x_3 = 1 \\ x_1 + 2x_2 + x_3 = -1 \\ x_1 + 3x_2 + 9x_3 = 1 \end{cases}$$
$$\text{令 } A = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 4 \\ 1 & 3 & 9 \end{bmatrix}, \quad X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ -1 \\ 1 \end{bmatrix}$$

如下的很多算法，在本科的计算方法的课程中也有学到。

### 3. 高斯消元法

$$\begin{aligned} [A|b] &= \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 2 & 4 & -1 \\ 1 & 3 & 9 & 1 \\ 1 & 1 & 1 & 1 \\ 0 & 1 & 3 & -2 \\ 0 & 0 & 1 & 2 \end{bmatrix} \\ &= \begin{bmatrix} 1 & 1 & 1 & 1 \\ 0 & 1 & 3 & -2 \\ 0 & 0 & 1 & 2 \end{bmatrix} \end{aligned}$$

$x_3 = 2, x_2 = -8, x_1 = 7$ 。  $\dim(A) = N$ , 计算复杂度  $O(N^3)$

### 4. LU 分解法

$$\begin{aligned} A = LU &\rightarrow \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \\ &= \begin{pmatrix} 1 & 0 & 0 \\ m_{21} & 1 & 0 \\ m_{31} & m_{32} & 1 \end{pmatrix} \begin{pmatrix} u_{11} & u_{12} & u_{13} \\ 0 & u_{22} & u_{23} \\ 0 & 0 & u_{33} \end{pmatrix} \end{aligned}$$

$Ax = b$  等价于  $LUx = b, Ux = y$

1.  $Ly = b$

2.  $Ux = y$

$$\begin{aligned} A = IA &= \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} 4 & 3 & -1 \\ -2 & -4 & 5 \\ 1 & 2 & 6 \end{pmatrix} \\ &= \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{2} & 1 & 0 \\ -\frac{1}{4} & 0 & 1 \end{pmatrix} \begin{pmatrix} 4 & 3 & -1 \\ 0 & -2.5 & 4.5 \\ 0 & 1.25 & 6.25 \end{pmatrix} \\ &= \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{2} & 1 & 0 \\ -\frac{1}{4} & \frac{1}{2} & 1 \end{pmatrix} \begin{pmatrix} 4 & 3 & -1 \\ 0 & -2.5 & 4.5 \\ 0 & 0 & 8.5 \end{pmatrix} \\ &= L \cdot U \end{aligned}$$

### 5. 迭代法(高斯消元)

$$\begin{cases} 4x - y + z = 7 \\ 4x - 8y + z = -21 \\ -2x + y + 5z = 15 \end{cases}$$

$$x_{k+1} = \frac{7 + y_k - z_k}{4}$$

$$y_{k+1} = \frac{21 + 4x_k + z_k}{8}$$

$$z_{k+1} = \frac{15 + 2x_k - y_k}{5}$$

算法:

1. 初始化  $(x_0, y_0, z_0)$ 。
2. 重复 (\*) 直至收敛。
3.  $(x_{k+1} - x_k)^2 + (y_{k+1} - y_k)^2 < \varepsilon$

假设  $(x_0, y_0, z_0) = (1, 2, 2)$

$k$	$x_k$	$y_k$	$z_k$
0	1	2	2
1	1.75	3.375	3
2	1.84375	3.875	3.025
$\vdots$			
15	1.99999993	2.99999993	3.9999985

如果调整两个式子的顺序:

$$\begin{cases} -2x + y + 5z = 15 \\ 4x - y + z = 7 \\ 4x - 8y + z = -21 \end{cases}$$

$$x_{k+1} = \frac{15 - y_k - 5z_k}{2}$$

$$y_{k+1} = \frac{21 + 4x_k + z_k}{8}$$

$$z_{k+1} = 7 - 4x_k + y_k$$

$k$	$x_k$	$y_k$	$z_k$
0	1	2	2
1	-1.5	3.375	5
2	6.6875	2.5	16.375
$\vdots$			
15	$\infty$	$\infty$	$\infty$

发现不收敛。引入判断算法收敛的方式: 对角占优矩阵。

$$A = \begin{pmatrix} 4 & -8 & 1 \\ 4 & -1 & 1 \\ -2 & 1 & 5 \end{pmatrix}$$

换顺序后： $A = \begin{pmatrix} -2 & 1 & 5 \\ 4 & -1 & 1 \\ 4 & -8 & 1 \end{pmatrix}$

定义：对角占优矩阵

矩阵  $A$  为严格对角占优矩阵，当且仅当：

$$\forall k, |a_{kk}| > \sum_{j=1, j \neq k}^N |a_{kj}|, \quad A \in \mathbb{R}^{N \times N}$$

若  $A$  为严格对角占优矩阵，则算法收敛。

证明：

$$Ax = b \Leftrightarrow x + (A - I)x = b$$

令  $D = \text{diag}(A)$ , 则  $Dx + (A - D)x = b$

$$x_{k+1} = D^{-1}(D - A)x_k + D^{-1}b$$

## 6. 高斯 - Sedel 法

$$\begin{cases} x_{k+1} = \frac{7+y_k-z_k}{4} \\ y_{k+1} = \frac{21+4x_{k+1}+z_k}{8}, \quad \text{加速计算} \\ z_{k+1} = \frac{15+2x_k-y_{k+1}}{5} \end{cases}$$

## 7. 优化法

考虑二次型函数：

$$f(x) = \frac{1}{2}x^T Ax - b^T x + c$$

定义梯度：

$$\nabla f(x) = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \vdots \\ \frac{\partial f(x)}{\partial x_N} \end{bmatrix}$$

假设  $A$  是对称的：

$$\nabla f(x) = Ax - b$$

有引理：

$$\frac{\partial x^T A x}{\partial x} = (A + A^T)x$$

$$\frac{\partial b^T x}{\partial x} = b$$

concentrate :  $\nabla f(x) = 0, \min f(X)$ 。

It's a critical point, only if  $A$  是半正定矩阵, 则  $\nabla f(x) = 0$  的解为  $\min f(x)$  的最小值点。

定义:  $A$  为半正定矩阵当且仅当  $\forall x \neq 0, x^T A x \geq 0$ 。

半正定和正定矩阵的详细定义和应用在优化方法基础一章。

## 8. 特征值法

我们将在[Lesson 5 监督学习之分类\(Perceptron, Fisher, Logistic, Softmax, Bayes\)](#)的菲谢尔线性判别分析中更详细学习特征值和特征向量的应用。

定义: 给定矩阵  $A \in \mathbb{R}^{N \times N}$ , 我们称  $\lambda$  为  $A$  的特征值,  $V$  为对应的特征向量, 当且仅当  $\lambda, V$  满足:

$$AV = \lambda V$$

$Ax = b$ , 假设  $A$  是对角化矩阵, 即存在可逆矩阵  $V$  和对角矩阵  $D$ , 使得  $A = VDV^{-1}$ 。

$$VDV^{-1} = b$$

如果存在非零向量  $x$ , 使得  $Ax = \lambda x$ 。则我们称  $x$  为  $A$  的特征向量,  $\lambda$  为  $A$  的特征值。

$$Ax = \lambda x = \lambda Ix \Leftrightarrow (\lambda I - A)x = 0$$

考虑一下两种情况:

1、 $\lambda I - A$  可逆

$$(\lambda I - A)^{-1} \cdot (\lambda I - A)x = 0$$

$$x = 0$$

2、 $\lambda I - A$  不可逆

$$\det(\lambda I - A) = 0$$

举例:  $A = \begin{pmatrix} 1 & 3 \\ -1 & 5 \end{pmatrix}$ 。

$$\det(\lambda I - A) = \det \begin{pmatrix} \lambda - 1 & -3 \\ 1 & \lambda - 5 \end{pmatrix} = (\lambda - 2)(\lambda - 4)$$

当  $\lambda = 2$  时, 由得到  $\begin{pmatrix} 1 & -3 \\ 1 & -3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0$ 。可得  $x_1 = 3, x_2 = 1$ , 即  $x = \begin{pmatrix} 3 \\ 1 \end{pmatrix}$ 。

若求  $Ax = b$ , 令  $A = S\Lambda S^{-1}$ 。

其中  $S = (x_1, \dots, x_n)$ ,  $\Lambda = \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix}$ 。其中  $Ax_i = \lambda_i x_i$ 。

$$AS = S\Lambda$$

$$\Leftrightarrow A(x_1 \cdots x_n) = (x_1 \cdots x_n) \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix}$$

$$\Leftrightarrow Ax_i = \lambda_i x_i$$

$$S\Lambda S^{-1}x = b \quad x^* = S^{-1}\Lambda^{-1}S$$